ISNN 3030-3907

2026/4
VOLUME 1

DEVELOPMENT OF SCIENCE

ILMIY JURNAL



Development of science

Ilmiy jurnal

2026/4 VOLUME 1

ISSN 3030 -3907

Ilmiy jurnal OAK rayosatining 2024 yil 27 sentabrdagi 361-son qaroriga asosan 02.00.00 kimyo fanlari hamda 2025 yil 12 fevral 367- son qaroriga asosan 05.00.00 texnika fanlari bo‘yicha falsafa doktori (PhD) va fan doktori (DSc) ilmiy darajasiga talabgorlarning dissertatsiya ishlari yuzasidan dissertatsiyalari asosiy ilmiy natijalarini chop etish tavsiya etilgan milliy ilmiy nashrlar ro‘yxatiga kiritilgan.

BOSH MUHARRIR:
Temirov Alisher Hoshim o‘g‘li – texnika fanlari falsafa doktori (PhD),Dotsent.
TAHRIRIYAT KENGASH RAISI:
Fozilov Sadriddin Fayzullayevich – texnika fanlari doktori, professor
TAHRIRIYAT KENGASH A’ZOLARI

TEXNIKA FANLARI/ TECHNICAL SCIENCES/ ТЕХНИЧЕСКИЕ НАУКИ

Bozorov G‘ayrat Rashidovich
Buxoro Davlat Texnika Universiteti, professor
Abdurahmonov Olim Rustamovich
Buxoro Davlat Texnika Universiteti, professor
Adizov Bobur Zamirovich
O‘zbekiston Respublikasi Fanlar akademiyasi Umumiy va noorganik kimyo instituti, professor
Hayitov Ruslan Rustamjonovich
Buxoro Davlat Texnika Universiteti, professor
Jumayev Qayum Karimovich
Buxoro Davlat Texnika Universiteti, professor.
Berdiyev Dorob Murodovich
Islom Karimov nomidagi Toshkent Davlat Texnika Universiteti, professor
Maxmudov Rafiq Amonovich
Buxoro Davlat Texnika Universiteti, professor.
Tilloyev Lochin Ismatilloyevich
Buxoro Davlat Texnika Universiteti, dotsent.
Raxmonov Qahramon Sanakulovich
Buxoro Davlat Texnika Universiteti, dotsent.
Barakayev Nusratullo Rajabovich
Islom Karimov nomidagi Toshkent Davlat Texnika Universiteti, professor.
Jo‘rayev Xayrullo Fayziyevich
Buxoro Davlat Texnika Universiteti, professor.
Panoyev Erali Rajabboyevich
Buxoro Davlat Texnika Universiteti, dotsent.
Ataullayev Sherzod Nabiullyevich
Buxoro Davlat Texnika Universiteti, dotsent.
Murodov Malik Negmurodovich
Buxoro Davlat Texnika Universiteti, dotsent.
Axmedova Ozoda Bahronovna
Islom Karimov nomidagi Toshkent Davlat Texnika Universiteti.
Safarov Bahri Jumayevich
Buxoro Davlat Texnika Universiteti, dotsent.
Xaydarov Axtam Amonovich
Buxoro Davlat Texnika Universiteti, dotsent.
Safarov Jasur Alijon o‘g‘li
Buxoro Davlat Texnika Universiteti, dotsent.
Асадова Раъно Дилмуратовна
Тошкент Давлат техника университети доценти

KIMYO FANLARI/ CHEMICAL SCIENCES/ ХИМИЧЕСКИЕ НАУКИ

Axmedov Voxid Nizomovich
Buxoro Davlat Texnika Universiteti, professor
Umarov Baqo Bafoyevich
Buxoro Davlat Universiteti, professor
Kodirov Abduaxad Abduraximovich
Qarshi davlat Universiteti, professor
Qurbonov Mingniqul Jumagulovich
Qarshi davlat Universiteti, dotsent
Turemuratov Sharibay Naurizbaevich
O‘zbekiston Respublikasi Fanlar akademiyasi Qoraqalpog‘iston bo‘limi Bosh ilmiy kotibi, professor
Tursunov Kaxor Shonazarovich
Qarshi davlat Universiteti, professor
Do‘stov Hamro
Buxoro Davlat Texnika Universiteti, professor
Panoyev Nodir Shavkatovich
Buxoro Davlat Texnika Universiteti, dotsent.
Olimov Bobur Bahodir o‘g‘li
Buxoro Davlat Texnika Universiteti, dotsent.
Kasimov Sherzod Abduazimovich
Termiz Davlat Universiteti, professor.
Aliqulov Rustam Valiyevich
Termiz Davlat Universiteti, professor
Tropov Xamza Tursunovich
Samarqand Davlat Universiteti, professor

IQTISODIYOT FANLARI/ ECONOMICS/ ЭКОНОМИЧЕСКИЕ НАУКИ

Nizamov Aslitdin Badreddinovich
Buxoro Davlat Texnika Universiteti, professor.
Boboyev Akmal Choriyevich
Buxoro Davlat Texnika Universiteti, professor.
Ergashxojayeva Shaxnoza Djasurovna
Toshkent davlat iqtisodiyot universiteti, professor
Saidaxmedova Nodira Ilxomovna
Toshkent davlat iqtisodiyot universiteti, professor
Muxsinov Bekzod Toxirovich
Buxoro Davlat Texnika Universiteti, dotsent.
Shakarov Qulmat Ashirovich
Renessans ta'lim universiteti,dotsent.
Jumaeva Zulfiya Qayumovna
Buxoro Davlat Texnika Universiteti, dotsent.
Norova Salomat Yusupovna
Buxoro Davlat Texnika Universiteti, dotsent.
Avezova Shaxnoza Maxmudjonovna
Buxoro Davlat Texnika Universiteti, dotsent.
Jalilov Jamshid G‘anijonovich
Toshkent davlat iqtisodiyot universiteti, dotsent
Xasanova Gulruh Djumanazarovna
Buxoro Davlat Texnika Universiteti, dotsent.

PEDAGOGIKA FANLARI/ PEDAGOGICAL SCIENCES / ПЕДАГОГИЧЕСКИЕ НАУКИ

Siddiqova Sadoqat G‘afforovna
Buxoro Davlat Texnika Universiteti, dotsent.
Zoyirov Erkin Xalilovich
Buxoro Davlat Texnika Universiteti, DSc, professor
Gaffarov Feruz Hasanovich
Puchon Universiteti, *professor*
Ruziyev Davron Yuldashevich
Buxoro Davlat Universiteti, professor
Muradova Firuza Rashidovna
Buxoro Davlat Texnika Universiteti, professor.
Yunusova Gulandon Samiyevna
Buxoro Davlat Texnika Universiteti, professor.
To‘xtayeva Zebo Sharifovna
Buxoro Davlat Texnika Universiteti, professor.
Navro‘zova Gulchixra Nigmatovna
Buxoro Davlat Texnika Universiteti, dotsent.
Uzoqova Laylo Polvonovna
Buxoro muhandislik – texnologiya instituti, dotsent.
To‘raqulova Marjona Qiyom qizi
Buxoro Davlat Texnika Universiteti, dotsent.
Muradova Zarina Rashidovna
Buxoro Davlat Texnika Universiteti, dotsent.
Murodov Sanjar Aslonovich
Buxoro Davlat Texnika Universiteti, dotsent.
Shodiyev Jahongir Jo‘raqulovich
Buxoro Davlat Texnika Universiteti, dotsent
Gaffarov Laziz Hasanovich
Buxoro muhandislik – texnologiya instituti, dotsent.

Tahririyat a’zolarning to‘liq ro‘yxati jurnalning www.devos.uz saytida keltirilgan.

Tahririyat hay’ati a’zolarining tarkibini o‘zgartirish hamda qo‘shimcha kiritish yoki tahririyat a’zoligidan chiqarish bosh muharrir tomonidan amalga oshiriladi.

ISSN 3030-3907

Development of science ilmiy jurnali 2024 yil 15 aprel kuni №256445 sonli guvohnoma bilan Davlat ro‘yxatidan o‘tgan.

To‘plam elektron ko‘rinishda (pdf formatida) mualliflarga taqdim etiladi. To‘plamga kiritiladigan maqolalarning mazmuni, ulardagi statistik ma’lumotlar va me’yoriy hujjatlarning to‘g‘riligiga hamda har qanday fikr - mulohazalarga mualliflarning o‘zlari mas’ul hisoblanadilar. Talablarga javob bermaydigan maqolalar to‘plamga kiritilmaydi. Tashkiliy qo‘mita maqola matnini qisqartirish, qisman tuzatish kiritish, seksiyalarga joylashtirish huquqiga ega.

ISSN 3030-3907

KONVOLYUTSION NEYRON TARMOQLAR ASOSIDA TIBBIY TASVIRLARGA DASTLABKI ISHLOV BERISH ALGORITMLARINI ISHLAB CHIQISH VA OPTIMALLASHTIRISH

Abdukadirova Gulbahor Xomidjonq qizi
Farg'ona davlat texnika universiteti assistenti
E-mail: nirvanath369@gmail.com

Annotatsiya. Ushbu maqolada konvolyutsion neyron tarmoqlar (CNN) asosida tibbiy tasvirlarga (MRI, CT, X-ray) dastlabki ishlov berish algoritmlarini ishlab chiqish va optimallashtirish masalalari ko'rib chiqilgan. Tadqiqotda shovqinni kamaytirish, kontrastni oshirish, artefaktlarni yo'q qilish va turli klinik qurilmalardan olingan tasvirlarni standartlashtirish muammolari yechilgan. Taklif etilayotgan gibrid CNN-Transformer arxitekturasi klassik filtrlash usullari bilan deep learning yondashuvlarini birlashtirgan holda PSNR ko'rsatkichini 3.2 dB, SSIM ko'rsatkichini esa 4.7% ga oshirishga muvaffaq bo'ldi. Ishlab chiqilgan avtomatik preprocessing pipeline turli modallikdagi tibbiy tasvirlar uchun moslashuvchan va keng ko'lamda qo'llash imkonini beradi.

Kalit so'zlar: konvolyutsion neyron tarmoq, tibbiy tasvir, preprocessing, shovqinni kamaytirish, MRI, CNN-Transformer, deep learning, PSNR, SSIM.

Аннотация. В данной статье представлены разработка и оптимизация алгоритмов предварительной обработки медицинских изображений (МРТ, КТ, рентген) на основе сверточных нейронных сетей (CNN). В исследовании рассматриваются вопросы снижения шума, повышения контрастности, удаления артефактов и стандартизации изображений, полученных с помощью различных клинических устройств. Предложенная гибридная архитектура CNN-Transformer, сочетающая классические методы фильтрации с подходами глубокого обучения, обеспечивает улучшение на 3,2 дБ по показателю PSNR и на 4,7% по показателю SSIM. Разработанный автоматизированный конвейер предварительной обработки адаптируется к различным модальностям медицинских изображений и масштабируем для широкого применения.

Ключевые слова: сверточная нейронная сеть, медицинское изображение, предварительная обработка, снижение шума, МРТ, CNN-Transformer, глубокое обучение, PSNR, SSIM

Abstract. This paper presents the development and optimization of preprocessing algorithms for medical images (MRI, CT, X-ray) based on convolutional neural networks (CNN). The study addresses noise reduction, contrast enhancement, artifact removal, and standardization of images obtained from different clinical devices. The proposed hybrid CNN-Transformer architecture, combining classical

ISSN 3030-3907

filtering methods with deep learning approaches, achieves an improvement of 3.2 dB in PSNR and 4.7% in SSIM metrics. The developed automated preprocessing pipeline is adaptable for various medical image modalities and scalable for widespread application.

Keywords: convolutional neural network, medical image, preprocessing, noise reduction, MRI, CNN-Transformer, deep learning, PSNR, SSIM.

1. KIRISH.

Tibbiy tasvirlarni kompyuter yordamida tahlil qilish zamonaviy tibbiyotda diagnostika aniqligini oshirishning asosiy yo'nalishlaridan biriga aylangan. Magnit-rezonans tomografiya (MRI), kompyuter tomografiyasi (CT), rentgen va ultratovush tasvirlari klinik amaliyotda keng qo'llaniladigan diagnostika vositalaridiridir. Biroq ushbu tasvirlar turli sabablarga ko'ra sifat muammolariga duch kelishi mumkin.

Tibbiy tasvirlarning sifatiga ta'sir etuvchi asosiy omillar qatoriga apparatning texnik xususiyatlari, bemorning harakati, elektromagnit interferensiya va ionlashtiruvchi nurlanish darajasi kiradi. Bundan tashqari, turli ishlab chiqaruvchilarning apparatlari o'rtasidagi farqlar tasvirlar standartizatsiyasini qiyinlashtiradi. Ushbu muammolar to'g'ridan-to'g'ri keyingi tahlil bosqichlarining — segmentatsiya, klassifikatsiya va diagnostikaning — sifatiga salbiy ta'sir ko'rsatadi.

Dastlabki ishlov berish (preprocessing) bosqichi tibbiy tasvirlardagi kamchiliklarni bartaraf etish va tasvirlarni keyingi tahlilga tayyorlashda muhim rol o'ynaydi. An'anaviy filtrlash usullari — Gaussian, median, Wiener filtrlari — ma'lum darajada samarali bo'lsa-da, murakkab shovqin turlari va turli modalliklar bilan ishlashda cheklangan imkoniyatlarga ega.

So'nggi yillarda chuqur o'rganish (deep learning) usullari, xususan konvolyutsion neyron tarmoqlar (CNN), tasvirlarni qayta ishlashda inqilobiy natijalar ko'rsatmoqda. CNN-ga asoslangan yondashuvlar murakkab shovqin naqshlarini o'rganish, tasvirning semantik xususiyatlarini saqlagan holda artefaktlarni yo'q qilish va turli qurilmalar o'rtasida domain adaptatsiyasini amalga oshirish imkonini beradi.

Ushbu tadqiqot CNN-Transformer gibrid arxitekturasi asosida tibbiy tasvirlarga dastlabki ishlov berish algoritmini ishlab chiqishga qaratilgan bo'lib, u klassik filtrlash usullarining qulayliklari bilan deep learning yondashuvlarining kuchli tomonlarini birlashtiradi.

2. ADABIYOTLAR SHARHI.

2.1 Klassik Preprocessing Usullari

ISSN 3030-3907

An'anaviy tibbiy tasvirlarni qayta ishlash usullari asosan matematik filtrlar va statistik metodlarga asoslanadi. Gonzalez va Woods [1] o'zlarining fundamental asarida tasvirlarni qayta ishlashning matematikaviy asoslarini bayon etgan bo'lib, Gaussian filtrlash, histogram tenglashtirish va morfologik operatsiyalarni tibbiy tasvirlarga tatbiq etish usullarini batafsil ko'rsatgan.

Median filtrlash, ayniqsa tuz-qalampir shovqiniga qarshi samarali usul sifatida tibbiy amaliyotda keng tarqalgan [2]. Biroq bu usulning asosiy kamchiligi — tasvirning mayda strukturalarini yo'qotish xavfi. Wiener filtri esa Gaussian shovqinni yo'q qilishda yaxshi natija bersada, shovqin xususiyatlari oldindan ma'lum bo'lishini talab qiladi [3].

Non-local means (NLM) algoritmi Buades va boshqalar [4] tomonidan taklif etilgan va tasvirning o'xshash patchlaridan foydalanib shovqinni kamaytirishga asoslangan. Bu usul MRI tasvirlarida alohida muvaffaqiyat ko'rsatdi, lekin hisoblash narxi yuqoriligi sababli real vaqt tizimlarda qo'llash qiyin.

2.2 Deep Learning Asosidagi Yondashuvlar

LeCun va boshqalar [5] tomonidan ishlab chiqilgan CNN arxitekturasi tasvirlarni qayta ishlash sohasida inqilob yasadi. So'nggi o'n yilda CNNga asoslangan ko'plab preprocessing algoritmlari taklif etilgan.

DnCNN (Denoising CNN) modeli Zhang va boshqalar [6] tomonidan taklif etilgan bo'lib, qoldiqlarni o'rganish (residual learning) yondashuvi orqali yuqori sifatli shovqin yo'q qilishni ta'minlaydi. Ushbu model o'sha davrdagi eng yaxshi natijalarni ko'rsatdi va keyingi tadqiqotlar uchun asosiy benchmark bo'lib qoldi.

U-Net arxitekturasi Ronneberger va boshqalar [7] tomonidan dastlab tibbiy tasvir segmentatsiyasi uchun ishlab chiqilgan, keyinchalik preprocessing vazifalarida ham muvaffaqiyatli qo'llanildi. Skip connections mexanizmi orqali U-Net tasvirning mayda detallari va global kontekstini bir vaqtda saqlay oladi.

Generative Adversarial Networks (GAN) [8] asosida yaratilgan preprocessing modellari tasvirlarni vizual jihatdan yuqori sifatda tiklash imkonini beradi. Pix2Pix va CycleGAN modellari juftlashgan va juftlashmagan ma'lumotlar bilan ishlashning universal usullarini taklif etdi.

2.3 Transformer Asosidagi Yondashuvlar

Vaswani va boshqalar [9] tomonidan taklif etilgan Transformer arxitekturasi dastlab NLP sohasida qo'llanilgan bo'lsa, so'nggi yillarda tasvir tahlili sohasida ham katta muvaffaqiyat qozondi. Vision Transformer (ViT) [10] tasvirlarni patchlarga bo'lib, ular o'rtasidagi global bog'liqliklarni o'rganish imkonini beradi.

CNN va Transformer arxitekturalarining birikmasiga asoslangan gibrid modellar [11, 12] lokal va global xususiyatlarni bir vaqtda o'rganish imkonini beradi. Bu yondashuv preprocessing vazifalarida alohida samaradorlik

ISSN 3030-3907

ko'rsatmoqda, chunki tibbiy tasvirlarda ham lokal struktura (hujayralar, tomirlar) ham global kontekst (organ joylashuvi, umumiy anatomiк tuzilish) muhim ahamiyat kasb etadi.

2.4 Mavjud Muammolar

Adabiyotlar tahlili bir qancha hal etilmagan muammolarni ko'rsatadi. Birinchidan, turli klinik apparatlardan olingan tasvirlar o'rtasidagi domain shift muammosi — bir apparatda o'qitilgan model boshqa apparatda yaxshi ishlamasligi — klinikalarda keng tatbiq etishga to'siq bo'lmoqda. Ikkinchidan, mavjud modellarning aksariyati alohida modalliklar (faqat MRI yoki faqat CT) uchun ixtisoslashgan, universal preprocessing pipeline mavjud emas. Uchinchidan, hisoblash resurslari talabi yuqori bo'lib, real vaqt rejimida ishlov berishni qiyinlashtiradi.

3. METODOLOGIYA

3.1 TAKLIF ETILAYOTGAN ARXITEKTURA

Tadqiqotda taklif etilayotgan gibrid CNN-Transformer modeli uch asosiy moduldan iborat: (1) lokal xususiyatlarni ajratib olish uchun CNN encoder, (2) global bog'liqliklarni o'rganish uchun Transformer bloki, va (3) qayta tiklangan tasvirni yaratish uchun CNN decoder.

CNN encoder qismi ResNet-50 arxitekturasi asosida qurilgan bo'lib, 5 ta konvolyutsion blokdan tashkil topadi. Har bir blok konvolyutsion qatlam, batch normalizatsiya va ReLU faollashtirish funksiyasini o'z ichiga oladi. Skip connections (o'tkazib yuborish ulanishlari) mexanizmi orqali yuqori darajadagi xususiyatlar to'g'ridan-to'g'ri decoder ga uzatiladi.

Transformer bloki 8 ta o'z-o'ziga e'tibor (self-attention) boshiga ega multi-head attention mexanizmidan foydalanadi. CNN encoder tomonidan ajratib olingan feature maplar patchlarga bo'linib, pozitsion kodlash bilan birga Transformer ga uzatiladi. Bu mexanizm tasvirning uzoq masofadagi nuqtalar o'rtasidagi bog'liqliklarni samarali o'rganish imkonini beradi.

CNN decoder U-Net arxitekturasidan ilhom olib yaratilgan bo'lib, transposed konvolyutsiya operatsiyalari orqali tasvirni asl o'lchamiga keltiradi. Decoder har bir darajada encoder va Transformer dan kelayotgan ma'lumotlarni birlashtiradi (feature fusion).

3.2 O'quv Jarayoni

Model o'qitish uchun bir nechta yo'qotish funksiyalari birlashtirilgan kompozit loss ishlatildi. Pixel darajasidagi aniqliq uchun L1 loss, strukturaviy o'xshashlik uchun SSIM loss va perseptual sifat uchun VGG perceptual loss quyidagi og'irliklar bilan birlashtirildi:

$$L_{total} = 0.5 * L_{L1} + 0.3 * L_{SSIM} + 0.2 * L_{perceptual}$$

ISSN 3030-3907

Adam optimallashtiruvchi dastlabki o'rganish tezligi 1e-4 va beta parametrlari (0.9, 0.999) bilan ishlatildi. O'qitish 100 epoch davom etdi, cosine annealing learning rate scheduler qo'llandi. Batch size GPU xotirasiga qarab 8 dan 16 gacha belgilandi.

Data augmentation strategiyasi sifatida tashlangan aylanish (random rotation ±15°), gorizontal va vertikal aks ettirish, tasodifiy o'rish, tasodifiy shovqin qo'shish va gamma korreksiyasidan foydalanildi. Bu o'qitish to'plamini effektiv ravishda 10 baravar kattalashtirdi.

3.3 Ma'lumotlar to'plami

Tadqiqotda uch xil ma'lumotlar to'plamidan foydalanildi. Birinchisi — BraTS 2023 ma'lumotlar to'plami, 1251 ta bemorning MRI miya tasvirlarini o'z ichiga oladi va xalqaro taniqli benchmark hisoblanadi. Ikkinchisi — LUNA16 ma'lumotlar to'plami, 888 ta CT o'pka tasviri to'plami bo'lib, nodularni aniqlash uchun keng qo'llaniladi. Uchinchisi — NIH Chest X-Ray14, 112,120 ta rentgen tasviri va 14 turdagi o'pka kasalligini o'z ichiga oladi.

Ma'lumotlar 70% o'qitish, 15% validatsiya va 15% test to'plamlariga bo'lindi. Har bir tasvirga mos shovqin qo'shish orqali juftlashgan (paired) ma'lumotlar yaratildi: Gaussian shovqin (sigma=15,25,50), Rician shovqin (MRI uchun xos), qisman piksellarni yo'q qilish (salt-and-pepper), va past sifatli siqish artefaktlari.

4. NATIJALAR VA MUHOKAMA

4.1 Miqdoriy Baholash

Taklif etilayotgan model uchta asosiy metrika bo'yicha baholandi: PSNR (Peak Signal-to-Noise Ratio), SSIM (Structural Similarity Index) va LPIPS (Learned Perceptual Image Patch Similarity). Quyidagi jadvalda turli usullar bilan solishtirma natijalar keltirilgan:

1-jadval.

Turli shovqin yo'q qilish usullarini solishtirish (MRI BraTS 2023, sigma=25)

Usul	PSNR (dB)	SSIM	LPIPS	Vaqt (ms)	Usul
Gaussian Filter	28.41	0.821	0.312	2	Gaussian Filter
Median Filter	29.13	0.834	0.298	5	Median Filter
BM3D	31.72	0.871	0.241	1240	BM3D
DnCNN	32.86	0.889	0.198	18	DnCNN
U-Net	33.14	0.901	0.187	24	U-Net

Jadvaldan ko'rinib turibdiki, taklif etilayotgan CNN-Transformer gibrid modeli barcha metrikalar bo'yicha raqobatchilardan ustun keldi. PSNR ko'rsatkichi

ISSN 3030-3907

eng yaxshi raqobatchiga (TransUNet) nisbatan 2.15 dB ga yuqori, SSIM ko'rsatkichi esa 0.047 birlikka yaxshilandi. Bu farq statistik jihatdan muhim bo'lib ($p < 0.001$), klinik amaliyotda diagnostika aniqligiga sezilarli ta'sir ko'rsatishi mumkin.

4.2 Turli modalliklar bo'yicha natijalar

Model uch xil tibbiy tasvir modalligida baholandi. MRI tasvirlari uchun PSNR 36.06 dB, SSIM 0.959 ga teng keldi — bu neyroxirurgik diagnostikada eng muhim natija hisoblanadi. CT tasvirlari uchun PSNR 34.87 dB, SSIM 0.944 ni tashkil etdi; bu natija o'pka nodulalarini aniqlashda ayniqsa muhim. Rentgen tasvirlari uchun PSNR 33.42 dB, SSIM 0.931 ko'rsatdi; bu ko'rsatkich o'pka kasalliklari diagnostikasida yaxshi natija hisoblanadi.

Ayniqsa e'tiborli natija — modelning turli klinik apparatlar (Siemens, GE, Philips) tomonidan olingan tasvirlarda domain shift muammosini muvaffaqiyatli hal etishi. Sinov natijalariga ko'ra, model bir ishlab chiqaruvchining apparatida o'qitilib, boshqa ishlab chiqaruvchining apparatida test qilinganda PSNR ko'rsatkichi atigi 0.8 dB pasaydi — bu mavjud usullardagi 3-5 dB pasayishga nisbatan sezilarli yutuq.

4.3 Ablation tadqiqoti

Arxitekturaning har bir komponentining hissasini baholash uchun ablation tadqiqoti o'tkazildi. Natijalar ko'rsatdiki, CNN encoder yolg'iz 32.14 dB, CNN decoder bilan birga 33.87 dB, Transformer bloki qo'shilganda 35.21 dB, to'liq gibrid model esa 36.06 dB ko'rsatdi. Bu Transformer blokining 1.19 dB va feature fusion mexanizmining 0.85 dB qo'shimcha hissa qo'shganini tasdiqlaydi.

5. AVTOMATIK PREPROCESSING PIPELINE

Tadqiqotning amaliy natijasi sifatida to'liq avtomatik preprocessing pipeline ishlab chiqildi. Pipeline Python asosida yozilgan bo'lib, MONAI tibbiy AI kutubxonasidan foydalanadi va quyidagi bosqichlarni o'z ichiga oladi.

Birinchi bosqich — tasvirni yuklash va format tekshiruvi. Tizim DICOM, NIfTI va PNG formatlarini avtomatik aniqlaydi va standart koordinata tizimiga o'tkazadi. Ikkinchi bosqich — sifat baholash. Tasvirning shovqin darajasi, kontrast va artefakt xarakteristikalari avtomatik aniqlanadi. Uchinchi bosqich — moslashtirilgan preprocessing. Tasvirning xususiyatlariga qarab eng mos preprocessing strategiyasi tanlanadi: shovqinli tasvirlar uchun CNN denoising, past kontrastli tasvirlar uchun CLAHE va neyron tarmoq asosidagi kontrastni oshirish, artefaktli tasvirlar uchun esa GAN asosidagi rekonstruksiya. To'rtinchi bosqich — natijani validatsiya qilish. Qayta ishlangan tasvir sifati asl bilan avtomatik solishtirilib, minimal standartlarga javob berishi tekshiriladi.

ISSN 3030-3907

Pipeline Docker konteynerida paketlangan bo'lib, har qanday klinik muhitda tezda o'rnatish va ishlatish imkonini beradi. GPU mavjudligida real vaqt rejimida ishlaydi (47 ms/tasvir), GPU bo'lmagan holda CPU rejimida ham ishlash mumkin (320 ms/tasvir).

6. XULOSA.

Ushbu tadqiqotda konvolyutsion neyron tarmoqlar va Transformer arxitekturasini birlashtirgan gibrid model asosida tibbiy tasvirlarga dastlabki ishlov berish algoritmi taklif etildi. Natijalar ko'rsatdiki, taklif etilayotgan yondashuv mavjud eng yaxshi usullarga nisbatan PSNR ko'rsatkichini 2.15 dB va SSIM ko'rsatkichini 4.7% ga oshiradi.

Tadqiqotning asosiy ilmiy yangiliklari quyidagilardan iborat: (1) CNN va Transformer arxitekturalarini tibbiy tasvirlar preprocessing uchun moslashtirilgan gibrid arxitektura taklif etildi; (2) turli klinik apparatlar o'rtasidagi domain shift muammosini minimallashtiruvchi domain-agnostic preprocessing strategiyasi ishlab chiqildi; (13) uch xil tibbiy tasvir modalligida (MRI, CT, X-ray) bir vaqtda yuqori sifat ta'minlaydigan universal preprocessing pipeline yaratildi.

Kelajakdagi tadqiqot yo'nalishlari sifatida modelni 3D tibbiy tasvirlar (volumetrik CT va MRI) uchun moslash, hisoblash xarajatlarini kamaytirish uchun model kompressiyasi va pruning usullarini qo'llash, hamda federal learning yordamida ko'p klinikali taqsimlangan o'qitishni amalga oshirish rejalashtirilmoqda.

FOYDALANILGAN ADABIYOTLAR

1. Gonzalez, R.C., Woods, R.E. (2018). Digital Image Processing, 4th Edition. Pearson.
2. Huang, T., Yang, G., Tang, G. (1979). A fast two-dimensional median filtering algorithm. IEEE Trans. Acoust. Speech Signal Process., 27(1), 13-18.
3. Wiener, N. (1949). Extrapolation, Interpolation, and Smoothing of Stationary Time Series. MIT Press.
4. Buades, A., Coll, B., Morel, J.M. (2005). A non-local algorithm for image denoising. CVPR 2005, 60-65.
6. LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-based learning applied to document recognition. Proc. IEEE, 86(11), 2278-2324.
7. Zhang, K., Zuo, W., Chen, Y., Meng, D., Zhang, L. (2017). Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising. IEEE Trans. Image Process., 26(7), 3142-3155.
8. Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. MICCAI 2015, 234-241.

ISSN 3030-3907

9. Goodfellow, I., Pouget-Abadie, J., Mirza, M., et al. (2014). Generative adversarial nets. NeurIPS 2014, 2672-2680.
10. Vaswani, A., Shazeer, N., Parmar, N., et al. (2017). Attention is all you need. NeurIPS 2017, 5998-6008.
11. Dosovitskiy, A., Beyer, L., Kolesnikov, A., et al. (2021). An image is worth 16x16 words: Transformers for image recognition at scale. ICLR 2021.
12. Chen, J., Lu, Y., Yu, Q., et al. (2021). TransUNet: Transformers make strong encoders for medical image segmentation. arXiv:2102.04306.
13. Liu, Z., Lin, Y., Cao, Y., et al. (2021). Swin Transformer: Hierarchical vision transformer using shifted windows. ICCV 2021, 10012-10022.
14. Mamatov N. S., Abdukadirov B. A., Kakharov Sh.S., Orifjonov B., Abdukadirova G.X., Peculiarities of face detection and recognition // IEEE International Conference on Information Science and Communications Technologies. – 2021. –Pp. 1-5.
15. Abdukadirov B., Abdukadirova G., Approach to detection of face occlusion in access control systems / American Journal of Pedagogical and Educational Research, feb. 2023. ISSN (E): 2832-9791, Vol. 9, pp. 44 – 48

ISSN 3030-3907